

Hybride Sensorfusion zur Fahrzeug-Umfelderkenennung und Fahrbereichsanalyse

Jan Effertz*

Zusammenfassung: Dieser Beitrag behandelt das Konzept für die maschinelle Wahrnehmung des Fahrzeugumfeldes von Team CarOLO im Rahmen der DARPA Urban Challenge 2007. Zum Einsatz kommt ein hybrides Umfeldmodell, das aus einem objektbasierten Tracking und einer kartenbasierten Befahrbarkeitsanalyse besteht. Im objektbasierten Teilsystem wird ein abstraktes Freiform-Objektmodell zur Konturverfolgung vorgestellt. Der kartenbasierte Systemzweig besteht aus einer dreidimensionalen Geländeprofil Darstellung und daraus abgeleitet aus einem probabilistischen Fahrbereichsmodell, das eine Quantifizierung der Befahrbarkeit bereit stellt. Als Datenquelle dient eine Reihe von Sensoren aus dem Bereich Fahrerassistenzsysteme und Bildverarbeitung. Die Systemzweige sind miteinander verbunden um eine Plausibilisierung der Objektdaten durch die Kartendarstellung zu ermöglichen.

Schlüsselwörter: Sensorfusion, Objekttracking, kartenbasiertes Umfeldmodell, Evidenztheorie

1 Einleitung

Die DARPA Urban Challenge im Jahr 2007 erforderte die vollständig autonome Fahrzeugführung im urbanen Fahrzeugumfeld. Die damit verbundene Situations-Komplexität macht den Einsatz eines leistungsfähigen und flexiblen Umfeldmodells für die Fahrzeugführung notwendig. Die Modellierung komplexer Randstrukturen (z.B. Absperrungen / Parklücken) stellt neue Herausforderungen an die Hinderniserkennung und -verfolgung, welche an die Grenzen der Leistungsfähigkeit des bisher im automobilen Umfeld üblichen, objektbasierten Umfeldmodells gehen.

Die TU Braunschweig hat sich diesen Herausforderungen mit ihrem Versuchsfahrzeug (Caroline) gestellt. Auf Basis herkömmlicher Sensorik aus dem Bereich Fahrerassistenzsysteme sowie Industrietechnik wurde ein hybrides Umfeldmodell erschaffen, das durch eine Freiform-Objektverfolgung und eine kartenbasierte Umfeld- und Fahrbereichsanalyse die Grundlage für eine sichere Fahrzeugführung darstellt.

2 Sensorkonzept

Zum Einsatz kommt ein Sensornetzwerk bestehend aus 5 verschiedenen Sensortypen (Abbildung 1) aus dem Bereich Radar, Lidar und Bildverarbeitung. Die Sensoren lassen sich

*Technische Universität Braunschweig, Institut für Regelungstechnik, Hans-Sommer-Str. 66, 38106 Braunschweig (e-mail: effertz@ifr.ing.tu-bs.de).




Abbildung 1: Sensorkonzept des Urban Challenge Versuchsfahrzeugs

in zwei grundsätzliche Kategorien gliedern, welche den Datenfluss im hybriden Umfeldmodell widerspiegeln.

- Drei Mehrebenen-Laserscanner (1), zwei Multibeam-Lidar Sensoren (2) sowie insgesamt vier Short- und Middlerange-Radarsensoren (3,6) werden für die Objektverfolgung einem herkömmlichen Trackingsystem zugeführt. Um auch komplexe Hindernisse und beliebig strukturierte Randbebauungen durch das Umfeldmodell abzubilden, wurde eine Freiform-Konturdarstellung auf Polygonbasis zum Einsatz gebracht (siehe Kapitel 4).
- Zwei Einebenen-Laserscanner (5), ein Stereokamerasystem (7) sowie eine Monokamera (4) werden für die kartenbasierte Umfelddarstellung genutzt (siehe Kapitel 5).

3 Systemarchitektur

Aufbauend auf diesen Eingangsdaten ergibt sich die in Abbildung 2 dargestellte Architektur. Objekttracking und das kartenbasierte Umfeldmodell sind miteinander verbunden, um mit Hilfe der in der Kartendarstellung vorhandenen 3D-Umfelddaten eine Plausibilisierung der sensorinternen Objektbildung zu ermöglichen. Die Umfelddarstellung erfolgt insgesamt einheitlich in einem erdfesten Bezugssystem. Die dazu notwendige Fahrzeugposition, -orientierung und -dynamik wird durch eine hochpräzise Ortungsplattform bestehend aus GPS und Inertialplattform zur Verfügung gestellt.

4 Objekttracking

Grundlage des Objekttrackings ist das Freiform-Konturmodell für die Beschreibung der erfassten Ziele. Jedes Objekt setzt sich hierbei aus einer geordneten Anzahl von N_p Konturpunkten zusammen, deren Verbindungsline die Objektform beschreibt. Dadurch ist es möglich, Hindernisse von beliebiger Struktur darzustellen, was für die Beschreibung

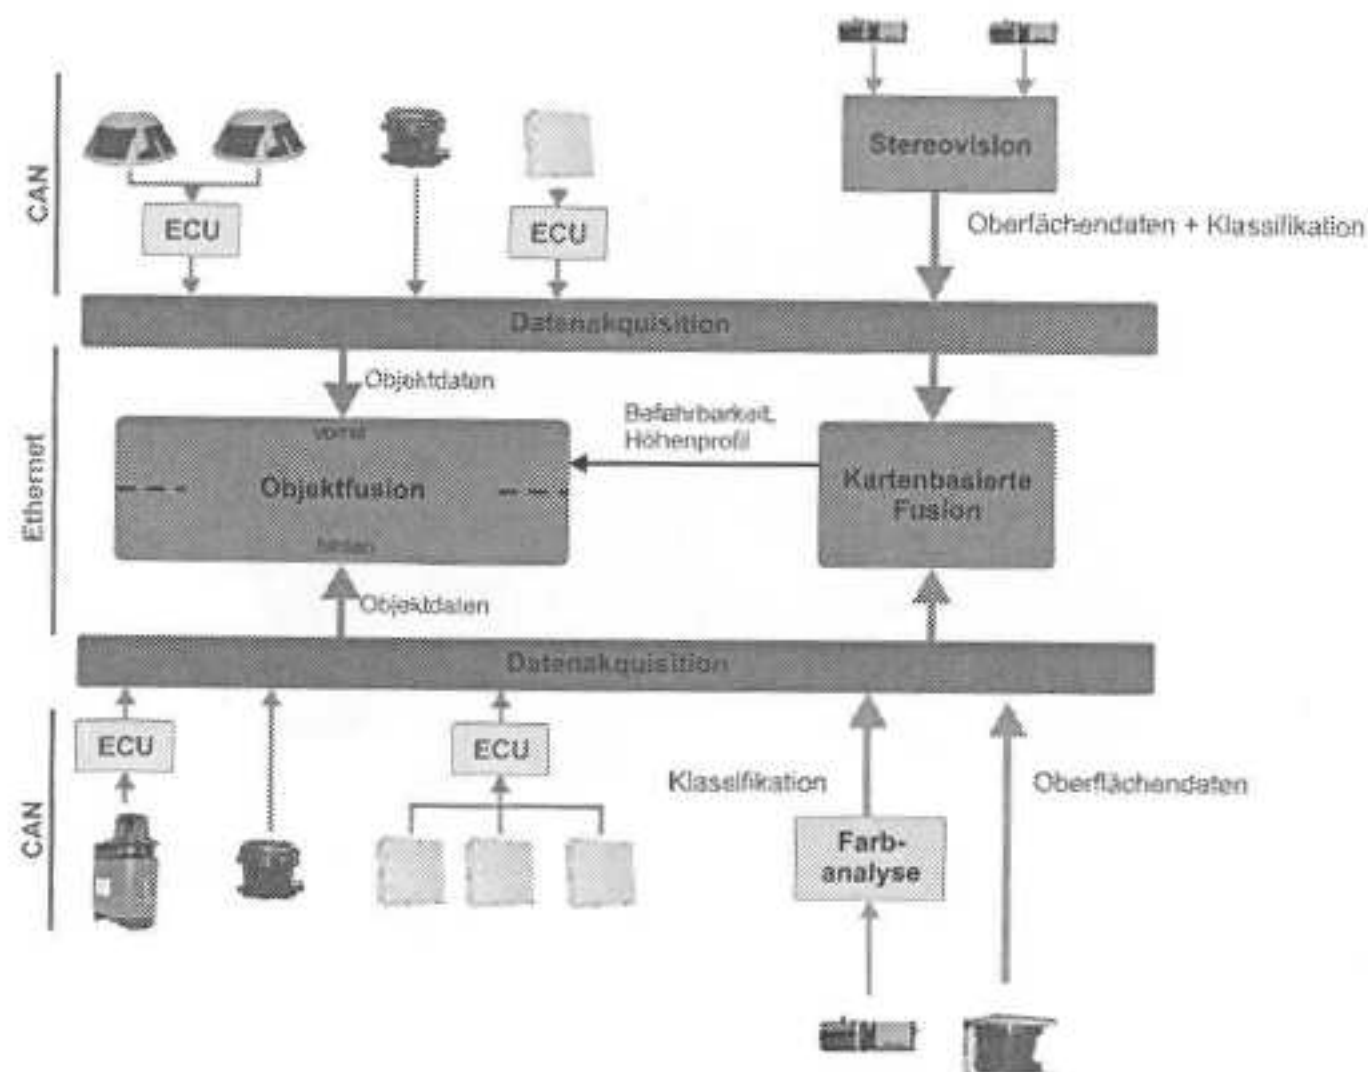


Abbildung 2: Systemarchitektur der Umfelderkennung

komplexer Umfeldsituationen im urbanen Umfeld von Vorteil ist. Als Bewegungsmodell kommt ein Coordinated Turn [4, 5] Prozessmodell zum Einsatz. Quer- und Längsbewegung eines Objekts sind über den Kurswinkel sowie dessen 1. Ableitung miteinander verknüpft. Zusätzlich ist eine kontinuierliche Geschwindigkeitsänderung über der Zeit möglich. Es ergibt sich folgender Zustandsvektor für die Objekte:

$$\mathbf{x} = [x_1 \ y_1 \ \dots \ x_{N_p} \ y_{N_p} \ v \ \phi \ a \ \dot{\phi}]^T. \quad (1)$$

Die Zustandsgrößen x_i und y_i beschreiben die Position des i -ten Konturpunkts, v ist die gemeinsame Objektgeschwindigkeit, ϕ der Kurswinkel, a die Beschleunigung und $\dot{\phi}$ die Kurswinkelgeschwindigkeit des Ziels. Als Ursprungspunkt der Gierbewegung wird näherungsweise der virtuelle Objekt-Schwerpunkt angesetzt, mit

$$s_x = \frac{1}{N_p} \sum_{i=1}^{N_p} x_i \quad \text{und} \quad s_y = \frac{1}{N_p} \sum_{i=1}^{N_p} y_i. \quad (2)$$

Es ergibt sich unter Berücksichtigung der Drehbewegung, den die Konturpunkte um ihr virtuelles Drehzentrum s_x und s_y durchführen, folgendes Prozessmodell:

$$\begin{aligned}
 \mathbf{x}[k+1] &= \mathbf{f}(\mathbf{x}[k]) \\
 &\Rightarrow \\
 x_i[k+1] &= x_i[k] + \frac{v[k] + \frac{1}{2}a[k] \cdot \Delta t}{\dot{\phi}[k]} \cdot \left(\sin(\phi[k] + \dot{\phi}[k] \cdot \Delta t) - \sin \phi[k] \right) + \\
 &\quad r_i[k] \cdot \left(\sin(\alpha_i[k] + \dot{\phi}[k] \cdot \Delta t) - \sin \alpha_i[k] \right) \\
 y_i[k+1] &= y_i[k] + \frac{v[k] + \frac{1}{2}a[k] \cdot \Delta t}{\dot{\phi}[k]} \cdot \left(\cos \phi[k] - \cos(\phi[k] + \dot{\phi}[k] \cdot \Delta t) \right) + \\
 &\quad r_i[k] \cdot \left(\cos \alpha_i[k] - \cos(\alpha_i[k] + \dot{\phi}[k] \cdot \Delta t) \right) \\
 v[k+1] &= v[k] + a \cdot \Delta t \\
 \phi[k+1] &= \phi[k] + \dot{\phi}[k] \cdot \Delta t \\
 a[k+1] &= a[k] \\
 \dot{\phi}[k+1] &= \dot{\phi}[k]
 \end{aligned} \tag{3}$$

Die Terme r_i und α_i sind der Abstand sowie der Öffnungswinkel jedes Konturpunkts in Bezug auf das Drehzentrum, Δt ist die Prädiktionsdauer. Sonderfälle treten für $\dot{\phi} = 0$ und $v = 0$ auf, die durch Umschalten auf ein geeignet niedriger dimensioniertes Zustandsraummodell behandelt werden. Dies ergibt zusätzlich den Vorteil, dass Objekte mit niedriger Dynamik durch eine geringere Anzahl von Zustandsgrößen beschrieben werden, wodurch deren Schätzgüte steigt.

Die Sensoren messen die Position der Konturpunkte, es ist jedoch nicht durch jeden Sensor oder in jedem Messzyklus eine vollständige Zielabdeckung gegeben. Eine weitere Stufe zur Konturverwaltung überwacht die Bestätigung einzelner Konturpunkte durch die eingehenden Sensordaten und berücksichtigt notwendige Konturveränderungen. Eine zweistufige Assoziation ermittelt für jedes Ziel die geeignete(n) Messung(en) für eine Zustandsaktualisierung sowie einen exakten Abgleich zwischen den Konturpunkten von Ziel und Messvektor. Das Messverfahren des Radarsensors ermöglicht zusätzlich eine Miteinbringung der Objektgeschwindigkeit in den Tracking-Prozess. Es ergibt sich der Messvektor

$$\mathbf{y} = \begin{pmatrix} x_1 & y_1 & \dots & x_{M_p} & y_{M_p} & v_x & v_y \end{pmatrix}^T \tag{4}$$

und darauf aufbauend die System-Ausgangsfunktion $\mathbf{h}(\mathbf{x})$ zu

$$\begin{aligned}
 \mathbf{y} &= \mathbf{h}(\mathbf{x}) \\
 &= \begin{pmatrix} \Theta \cdot \mathbf{x}_{pos} \\ v \cdot \cos \phi \\ v \cdot \sin \phi \end{pmatrix}.
 \end{aligned} \tag{5}$$

Hierbei ist M_p die Anzahl der durch den Sensor gemessenen Konturpunkte (ein Punkt beim Radar, zwei Punkte beim Multibeam-Lidar und bis zu 32 Punkte beim Laserscanner), Θ das Ergebnis der Konturassoziation im Rahmen der Datenzuordnung und \mathbf{x}_{pos} der Zielvektor der Konturpunktskoordinaten. Der Geschwindigkeitsvektor steht nur beim Radarsensor zur Verfügung.

Die Zustandsschätzung wird für das Freiform-Modell durch eine Reihe von Effekten verkompliziert:

- Die Sensoren messen nicht (immer) alle Konturpunkte des Ziels. Nicht gemessene Konturpunkte sind nicht beobachtbar und müssen als prädizierter Wert weitergegeben werden.
- Das Prozessmodell ist über die Drehbewegung verkoppelt für alle Konturpunkte, die Jacobi-Matrix der Systemübertragungsfunktion ist entsprechend aufwendig in der Berechnung.
- Durch die variable Anzahl an Konturpunkten sowie die partielle Beobachtbarkeit ergibt sich die Notwendigkeit einer beständigen Dimensionsanpassung der Kovarianzmatrizen und Zustandsvektoren für jede Formveränderung, was den Echtzeitanforderungen des Systems im Wege steht.
- Die Innovations-Kovarianz ist M_p -dimensional für jede Messung (Messvektor ohne Geschwindigkeit), die Invertierung der $M_p \times M_p$ Matrix ist entsprechend rechenzeintensiv.

Um dennoch einen Realzeitbetrieb zu ermöglichen, werden für den Schätzvorgang die Objekte und Messvektoren virtuell auf ihren Schwerpunkt reduziert. In der Prädiktion der Schätzfehlerkovarianz eliminiert diese Vorgehensweise die Verkopplung der Konturpunkte untereinander, die Unsicherheit des Messvektors wird nur in Bezug auf den virtuellen Schwerpunkt ausgedrückt. Die Matrixdimensionen von Schätzfehler-Kovarianz, Messrauschen und Innovation reduziert sich durch diese Näherung entsprechend auf die Dimension 6×6 und 2×2 bzw. 4×4 (Messung der Geschwindigkeit). Die Kalmanverstärkung muss für den Schätzvorgang eines Objekts nur ein einziges Mal berechnet werden und ist für alle Konturpunkte identisch.

Die Reduktion erfolgt nur virtuell, so dass im Zustands- und Messvektor weiterhin alle Konturpunkte mitgeführt werden. Dies ermöglicht eine korrekte Assoziation unter Berücksichtigung der Zielausdehnung. Der Korrekturvektor für die Schätzung jedes Punktes wird über alle Konturpunkte gemittelt und anschließend für die Aktualisierung der Objektdynamik herangezogen. Auf Basis eines erweiterten Kalmanfilters [1, 2] ergibt sich folgender Schätzalgorithmus:

$$\begin{aligned}
 \mathbf{x}[k+1|k] &= \mathbf{f}(\mathbf{x}[k]), \\
 \mathbf{P}[k+1|k] &= \mathbf{F}[k] \cdot \mathbf{P}[k] \cdot \mathbf{F}[k]^T + \mathbf{Q}[k], \\
 \mathbf{S}[k+1] &= \mathbf{H}[k+1] \cdot \mathbf{P}[k+1|k] \cdot \mathbf{H}[k+1]^T + \mathbf{R}[k+1], \\
 \mathbf{K}[k+1] &= \mathbf{P}[k+1|k] \cdot \mathbf{H}[k+1]^T \cdot \mathbf{S}[k+1]^{-1}, \\
 \mathbf{r}^i[k+1] &= \mathbf{K}[k+1] \cdot (\mathbf{y}^i[k+1] - \mathbf{h}(\mathbf{x}^i[k+1|k])), \\
 \mathbf{x}^i[k+1]\{1:2\} &= \mathbf{x}^i[k+1|k]\{1:2\} + \mathbf{r}^i[k+1]\{1:2\}, \\
 \mathbf{x}[k+1]\{3:6\} &= \mathbf{x}[k+1|k]\{3:6\} + \frac{1}{M_p} \sum_{i=1}^{M_p} \mathbf{r}^i[k+1]\{3:6\} \quad \text{und} \\
 \mathbf{P}[k+1] &= (\mathbf{I} - \mathbf{K}[k+1]\mathbf{H}[k+1]) \cdot \mathbf{P}[k+1|k].
 \end{aligned} \tag{6}$$

Hierbei ist \mathbf{P} die Schätzfehler-Kovarianzmatrix, \mathbf{F} die Jacobi-Matrix der Systemübertragungsfunktion $\mathbf{f}(\mathbf{x})$ (reduziert auf die Schwerpunktsbewegung), \mathbf{Q} die Kovarianzmatrix des Prozessrauschens, \mathbf{S} die Kovarianz der Innovation, \mathbf{H} die Jacobi-Matrix der System-Ausgangsfunktion $\mathbf{h}(\mathbf{x})$ und \mathbf{K} die Kalmanverstärkung. Der Vektor \mathbf{x}^i ist der Zustandsvektor reduziert auf den Konturpunkt i , \mathbf{y}^i der Messvektor für die entsprechende Konturpunkts-Assoziation und \mathbf{r}^i ist der Korrekturvektor für den betrachteten Mess- und Konturpunkt i .

Eine informationstheoretische Analyse der getroffenen Näherung zeigt, dass zum einen über die Vernachlässigung der Konturpunktsverkopplung im Zustandsvektor der Kurswinkel einzig über die Schwerpunktsposition bestimmt wird, während bei einer idealen Kalmanfilterapplikation auch die Drehung der Kontur für eine Schätzung des Kurswinkels mit herangezogen wird. Dieser Preis muss für die Realzeitapplikation mit hoher Zieldichte im urbanen Umfeld in Kauf genommen werden. Zum anderen wird für alle Messpunkte und Konturpunkte über den virtuellen Schwerpunkt eine gleiche Schätzfehlerkovarianz bzw. Messrauschkovarianz gefordert. Diese Näherung hat für Ziele mit begrenzter Ausdehnung, welche die Mehrzahl der erwarteten Objekte im urbanen Umfeld stellen, eine entsprechend kleine Auswirkung. Über die Sammel-Schätzfehlerkovarianz bezogen auf den Objektschwerpunkt wird zusätzlich das individuelle Ansteigen der Schätzunsicherheit für einen nicht assoziierbaren Konturpunkt vernachlässigt. Dies kann über das Einführen eines Systemrausch-Strafterms, der die Anzahl der erfolgreich assoziierten Konturpunkte berücksichtigt, teilweise kompensiert werden. Die getroffenen Näherungen zeigen sich als guter Kompromiss, um Freiform-Konturschätzung und gleichzeitige Realzeitapplikation zu ermöglichen.

5 Kartenbasiertes Umfeldmodell

Die kartenbasierte Umfeldmodellierung verfolgt im Gegensatz zum Objekttracking den Ansatz, eine gleichmäßige und flächige Beschreibung der Umwelt bereitzustellen. Dies schließt die Bereiche ein, in denen keine relevanten Hindernisse erfasst wurden (Freibereichsmodellierung). Im Rahmen dieses Beitrags wird hierzu zunächst mit Hilfe der Messpunkte der Einebenen-Laserscanner sowie der Stereobildverarbeitung eine Höhenkarte des Fahrzeugumfelds erzeugt. Hierbei ist das Messprinzip der Sensoren zu berücksichtigen, welches eine direkte Sichtverbindung zwischen Sensorursprung und Messpunkt voraussetzt. Für den Strahlengang vom Ursprung zum Messpunkt wird Hindernisfreiheit gefordert. Die Messdaten werden über ein Raytracing-Verfahren in die Karte eingetragen, wobei für eine effiziente und echtzeitfähige Implementierung der Bresenham-Algorithmus [6] zum Einsatz kommt. Abbildung 3 visualisiert diesen Vorgang. Grundlage ist eine effiziente Kartenstruktur, die den Bresenham-Algorithmus erleichtert und einen effizienten Zugriff auf jedes Kartenelement ermöglicht. Es wurde hierzu eine ringförmig verkettete und blockweise strukturierte Karte implementiert, die eine inkrementelle Navigation von Zelle zu Zelle ermöglicht. Die blockweise Speicherung des Karteninhalts ist so angelegt, dass die Blöcke als Ganzes im Prozessorcache der Rechenplattform vorgehalten werden können. Dies minimiert Speicherzugriffe und erhöht die Verarbeitungsgeschwindigkeit. Der Block im Kartenzentrum definiert den Kartenbezugspunkt, von dem aus jede beliebige Position im Weltkoordinatensystem aufgesucht werden kann. Die Fahrzeugeigenposition wird im Bezugsblock gehalten, so dass bei einer Eigenbewegung über die Blockgrenze




Abbildung 3: Raytracing der Kartendaten

hinaus am virtuellen Kartenhorizont eine effiziente Neuinitialisierung des Karteninhalts erfolgen kann. Abbildung 4 visualisiert dies für den Übergang von einem Bezugsblock zum nächsten. Auf Basis der Höhendaten erfolgt zunächst die Approximation der Fahrbahne-

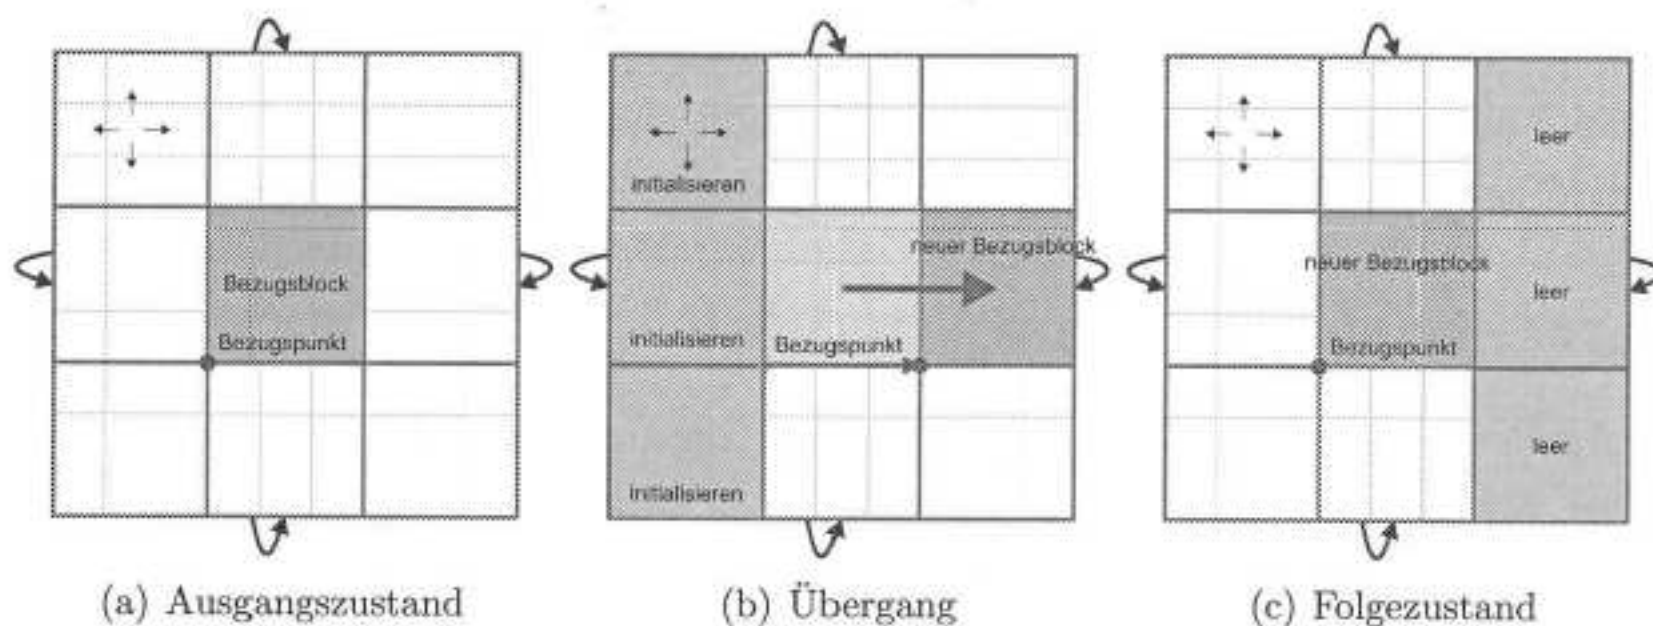


Abbildung 4: Ringförmig verkettete Karte in Blockstruktur

bene. Grundlage für diese Approximation ist ein gewichtetes Least-Squares Verfahren [10], dessen Eingangsdaten durch eine Reihe von Messpunkten vor der Fahrzeugfront definiert sind. Als Wichtung wird die später ermittelte Befahrbarkeit des Untergrundes herangezogen.

Durch Höhenvergleich zwischen Fahrbahnebene und Karteninhalt kann eine einfache Hinderniserkennung realisiert werden [3]. Im Rahmen dieses Beitrags wird darüber hinaus eine probabilistische Befahrbarkeitsanalyse durchgeführt. Die Karte wird hierzu erweitert um eine Dempster-Shafer [7] Beschreibung (DS) für jede Zelle z , die den Wahrscheinlichkeits-Potenzraum

$$2^{\Theta} = \{befahrbar, unbefahrbar, unbekannt\} \quad (7)$$

durch eine Massenverteilung

$$\begin{aligned}
 M_z(D) &= M[\text{befahrbar}] \in [0.0, 1.0], \\
 M_z(U) &= M[\text{unbefahrbar}] \in [0.0, 1.0], \\
 M_z(N) &= M[\text{unbekannt}] \in [0.0, 1.0] \quad \text{mit} \\
 M_z(D) + M_z(U) + M_z(N) &= 1.0
 \end{aligned} \tag{8}$$

beschreibt. Als Maß der Unbefahrbarkeit dient der Gradient der Höhenkarte $\frac{\partial h}{\partial x \partial y}$ an der betreffenden Zelle. Der Gradient wird über das Sensormodell

$$\begin{aligned}
 M_m(D) &= \begin{cases} D_{max}, & \left| \frac{\partial h}{\partial x \partial y} \right| \leq G_{D_{max}} \\ 0, & G_{D_{max}} < \left| \frac{\partial h}{\partial x \partial y} \right| \leq G_{U_{min}} \\ 0, & \left| \frac{\partial h}{\partial x \partial y} \right| > G_{U_{min}} \end{cases} \\
 M_m(U) &= \begin{cases} 0, & \left| \frac{\partial h}{\partial x \partial y} \right| \leq G_{D_{max}} \\ \frac{U_{max}}{G_{U_{min}} - G_{D_{max}}} \cdot \left(\left| \frac{\partial h}{\partial x \partial y} \right| - G_{D_{max}} \right), & G_{D_{max}} < \left| \frac{\partial h}{\partial x \partial y} \right| \leq G_{U_{min}} \\ U_{max}, & \left| \frac{\partial h}{\partial x \partial y} \right| > G_{U_{min}} \end{cases} \\
 M_m(N) &= 1 - m_m(D) - m_m(U),
 \end{aligned} \tag{9}$$

in eine äquivalente DS-Massenverteilung überführt. Die Terme $G_{D_{max}}$ und $G_{U_{min}}$ sind der maximal zulässige Gradient für vollständige Befahrbarkeit sowie der minimale Gradient für vollständige Unbefahrbarkeit, D_{max} und U_{max} sind die zugeordneten Werte der DS-Massenverteilung. Die vier Parameter dienen der Empfindlichkeits-Parametrierung des Algorithmus.

Die zeitliche Integration der Messdaten in die Kartenstruktur erfolgt durch Anwendung der Dempster'schen Kombinationsregel, mit:

$$M_z^*(A) = M_z(A) \oplus M_m(A) = \frac{1}{1 - K} \sum_{B \cap C = A \neq \emptyset} M_z(B) M_m(C), \tag{10}$$

Der Term K drückt hierbei den Konflikt zwischen den neu eingegangenen Sensorinformationen (Gradient an der Zelle z) und der bestehenden Karteninformation aus. Es gilt:

$$K = \sum_{B \cap C = \emptyset} M_z(B) M_m(C). \tag{11}$$

Die Darstellung auf Basis der Evidenztheorie ist ähnlich zum Bayes'schen Ansatz der Belegungskarten [9], jedoch ist in der Dempster-Shafer-Notation eine explizite Quantifizierung des Unwissens $M_z[N]$ sowie die Quantifizierung des Konfliktes möglich. Weiterhin ist nicht die Zellbelegung Gegenstand des Interesses sondern die Zellbefahrbarkeit, da auch freie Bereiche des Umfeldes potentiell nicht befahrbar sein können (z.B. der Grünstreifen neben der Fahrbahn).

An dieser Stelle werden die Messdaten der Mono-Farbkamera mit in den Erfassungsprozess eingebunden. Im Rahmen der Vorverarbeitung wird hierbei für jeden Bildpunkt die Ähnlichkeit P_d zur augenblicklichen Farbe des Straßenbelages bestimmt [8] und in einem Wertebereich

- 0.0: keine Ähnlichkeit bis
- 1.0: identisch

quantifiziert. Die Ähnlichkeit wird anschließend in eine äquivalente DS-Massenverteilung überführt. Es gilt hierbei:

$$\begin{aligned} M_m(D) &= D_{max} \cdot P_d, \\ M_m(N) &= (1 - D_{max}), \\ M_m(U) &= 1 - m_m(D) - m_m(N). \end{aligned} \quad (12)$$

Der Wert D_{max} ist ein Justageparameter, der das Vertrauen in die Ergebnisse der Bildverarbeitung wichtet. Es ergibt sich die in Abbildung 5 dargestellte Befahrbarkeitsanalyse. Die Farbkodierung rot, grün und blau entspricht der Unbefahrbarkeit, Befahrbarkeit und




Abbildung 5: Ergebnis der Befahrbarkeitsanalyse

der Unbekanntheit der Zellinhalte, die probabilistische Beschreibung wurde hierbei auf die Höhenkarte des Umfeldes projiziert.

6 Zusammenfassung und Ausblick

Es wurde das hybride Umfeldmodell des Urban Challenge Wettbewerbsfahrzeugs der TU Braunschweig vorgestellt. Dieses besteht aus einem klassischen Objekttracking, das um eine kartenbasierte Geländeprofil- und Befahrbarkeitsdarstellung auf Basis der Evidenztheorie ergänzt ist. Beide Ansätze vereinigen die Messdaten mehrerer Sensorquellen im Rahmen einer Sensorfusion. Das Objekttracking ist gut geeignet für die Beschreibung dynamischer Hindernisse, was in der statischen Kartendarstellung direkt nicht möglich ist. Durch eine Freiform-Modellierung der Objektdaten sind hierbei beliebige Zielkonturen möglich. Die Kartendarstellung ist gut geeignet für eine statische Hindernisdarstellung und durch die probabilistische Befahrbarkeitsanalyse wird die Fusion verschiedener Sensorquellen (LIDAR, Bildverarbeitung) für eine Approximation des Fahrbahnverlaufes

realisiert.

Gegenwärtig erfolgt die Objektbildung der Fahrerassistenzsensorik auf den Steuergeräten der Sensoren selbst, das Objekttracking verwendet diese Eingangsdaten für den Aufbau des Umfeldmodells. Die sensorinterne Objektbildung wird plausibilisiert durch einen Abgleich mit der kartenbasierten Befahrbarkeitsanalyse, um unerwünschte Bodenreflexionen zu unterdrücken und die Hinderniserfassung zu optimieren. Die Datenbasis der Karte geht nur unterstützend in den Tracking-Prozess mit ein. Für zukünftige Entwicklungen ist eine Integration der Objektbildung in die Kartendarstellung wünschenswert, um die Clusterbildung als Vorbereitung der Freiform-Konturverfolgung zu optimieren. Es ist ferner möglich, die statischen Hindernisdaten einzig auf Basis der Kartendarstellung zu verwalten, insofern die nachgeschaltete Applikation keine Objektbildung und/oder Datenreduktion erfordert. Dies ist insbesondere aussichtsreich für eine Verwendung moderner Mehrebenen-Laserscanner, die durch ihre reichhaltige Messdateninformation eine entsprechend detaillierte Umfeldkarte aufbauen können.

Literatur

- [1] Y. Bar-Shalom, T. E. Fortmann, *Tracking and Data Association* Academic Press Inc., Orlando, Florida, 1988.
- [2] S. S. Blackman, *Multiple-Target Tracking with Radar Applications*, Artech House, 1986.
- [3] M. Darms, P. E. Rybski, C. Urmson *Vehicle Detection and Tracking for the Urban Challenge*, AAET 2008 Automatisierungssysteme, Assistenzsysteme und eingebettete Systeme für Transportmittel, pp. 260-277, 2008.
- [4] S. M. Herman *A Particle Filtering Approach to Joint Passive Radar Tracking and Target Classification*, University of Illinois at Urbana-Champaign, 2002.
- [5] M. Maehlich, T. Kauderer, W. Ritter, K. C. J. Dietmayer, *Feature-Level Video and Multibeam Lidar Sensor Fusion for Full-Speed ACC State Estimation* In Proceedings of 4th International Workshop on Intelligent Transportation. Hamburg, Germany, pp. 173-178, 2007.
- [6] M. L. V. Pitteway, *Algorithmn for Drawing Ellipses or Hyperbolae with a Digital Plotter*, Computer Journal 10(3), 282-289, November 1967.
- [7] G. Shafer, *A Mathematical Theory of Evidence*, Princeton University Press, 1976.
- [8] S. Thrun, S. et al., *Stanley: The Robot That Won The DARPA Grand Challenge*, Technical report, Stanford University, Stanford, 2005.
- [9] S. Thrun, W. Burgard, D. Fox, *Probabilistic Robotics*, The MIT Press, Massachusetts Institute of Technology, Cambridge, Massachusetts, 2005.
- [10] J. W. Weingarten, G. Gruener, R. Siegwart, *Probabilistic plane fitting in 3D and an application to robotic mapping* Proceedings. ICRA '04. 2004 IEEE International Conference on Robotics and Automation 2004, Vol. 1, pp. 927- 932, 2004